



Continuous Rainfall-Runoff Simulation by Artificial Neural Networks Based on Selection of Effective Input Variables Using Partial Mutual Information (PMI) Algorithm

M. Shafeizadeh¹, H. Fathian^{2*}, and A.R. Nikbakht Shahbazi³

Abstract

Knowledge on the natural potential of basins is one of fundamental needs to optimal utilization of runoff and thus, rainfall-runoff simulation in basins is of utmost importance. Continuous simulation of rainfall-runoff in Maroun basin is performed in this study using Artificial Neural Networks (ANNs) in order to evaluate the ability and accuracy of ANN for runoff estimation. Considering the fact that the number of rainy days per year is less than sunny days, so runoff is caused by two different mechanisms. In continuous rainfall time and a few days later, runoff mainly is from high discharge and low base time. But on most days, when there is no rainfall, low baseflow and long base time form the outflow. Thus, in this research a dual criteria model of rainfall-runoff including model on rainy days and non-rainy days were examined. Also the input variables effective on runoff in the Maroun basin are determined using the partial mutual information (PMI) algorithm. Comparison of statistical criteria between the single criterion model and dual criteria model indicated that the latter was more accurate. Therefore, the Nash-Sutcliffe coefficient of single criterion model and dual criteria model for test stage of network were 0.86 and 0.94 respectively.

Keywords: Artificial Neural Networks, PMI Algorithm, Continuous Rainfall-Runoff Simulation.

Received: August 11, 2018

Accepted: February 16, 2019

شبیه‌سازی پیوسته بارش - رواناب با استفاده از شبکه‌های عصبی مصنوعی بر مبنای انتخاب متغیرهای مؤثر ورودی با الگوریتم اطلاعات متقابل جزئی (PMI)

مهرداد شافعی‌زاده^۱، حسین فتحیان^{۲*} و علیرضا نیکبخت شهبازی^۳

چکیده

آگاهی از توان طبیعی تولید رواناب در حوضه‌های آبریز یکی از نیازهای اساسی برای برنامه‌ریزی اصولی جهت بهره‌برداری بهینه از رواناب می‌باشد. از این رو شبیه‌سازی بارش - رواناب در حوضه‌های آبریز از اهمیت زیادی برخوردار می‌باشد. در این مقاله به شبیه‌سازی پیوسته بارش - رواناب در حوضه سد مارون با شبکه‌های عصبی مصنوعی پرداخته شد تا توانایی و دقت این شبکه در برآورد رواناب ارزیابی گردد. با توجه به اینکه تعداد روزهای بارندگی در هر سال کمتر از روزهای غیر بارندگی می‌باشد، بنابراین محاسبه رواناب خروجی از حوضه ناشی از دو مکانیسم متفاوت خواهد بود. در زمان‌های همراه با وقوع بارش و چند روز بعد از آن، رواناب خروجی از حوضه عمدتاً به صورت سیلاب‌های با دبی زیاد و تداوم کم می‌باشد. ولی در اکثر روزهای سال که بارندگی وجود ندارد، رواناب خروجی به صورت جریان پایه با مقادیر دبی کم و با تداوم زیاد می‌باشد. بنابراین در این تحقیق یک مدل بارش - رواناب دو ضابطه‌ای شامل مدل مربوط به روزهای بارانی و مدل مربوط به روزهای غیربارانی ارائه شد. همچنین متغیرهای ورودی مؤثر بر دبی جریان در حوضه مارون با استفاده از الگوریتم اطلاعات متقابل جزئی (PMI) تعیین شد. مقایسه مقادیر معیارهای آماری بین مدل تک‌ضابطه‌ای و مدل دوضابطه‌ای نشان داد که دقت مدل دوضابطه‌ای در برآورد دبی جریان در ایستگاه ایدنک بیشتر از دقت مدل تک‌ضابطه‌ای بود. بطوری که ضریب ناش - ساتکلایف برای مدل تک‌ضابطه‌ای و دوضابطه‌ای به ازای مرحله آزمون شبکه به ترتیب برابر با ۰/۸۶ و ۰/۹۴ بود.

کلمات کلیدی: شبکه‌های عصبی مصنوعی، الگوریتم PMI، شبیه‌سازی پیوسته بارش - رواناب.

تاریخ دریافت مقاله: ۹۷/۵/۲۰

تاریخ پذیرش مقاله: ۹۷/۱۱/۲۷

1- M.Sc. Graduate of Water Resources Engineering, Ahvaz Branch, Islamic Azad University, Ahvaz, Iran.

2- Assistant Professor, Department of Water Sciences and Engineering, Ahvaz Branch, Islamic Azad University, Ahvaz, Iran. Email: Fathian.h58@gmail.com

3- Assistant Professor, Department of Water Sciences and Engineering, Ahvaz Branch, Islamic Azad University, Ahvaz, Iran.

*- Corresponding Author

۱- دانش‌آموخته کارشناسی ارشد مهندسی منابع آب، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران.

۲- استادیار گروه علوم و مهندسی آب، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران.

۳- استادیار گروه علوم و مهندسی آب، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان پائیز ۱۳۹۸ امکانپذیر است.

علاوه بر دقت قابل قبول در پیش‌بینی نقطه‌ای و بلند مدت جریان، امکان پیش‌بینی به صورت مجموعه‌ای از جریان‌های ممکن را نیز فراهم می‌آورد. (Dastourani et al. (2011) کارایی شبکه عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی به منظور برآورد بارش- رواناب در حوضه سد زاینده‌رود را مورد ارزیابی قرار دادند. نتایج نشان داد که شبکه عصبی مصنوعی و سیستم فازی- عصبی در شرایط مختلف و با ترکیب‌های مختلف پارامترهای ورودی، نتایج متفاوتی از خود نشان می‌دهند، ولی در کل این دو روش به میزان قابل قبولی قادر به تخمین رواناب حاصل از بارش با به کارگیری پارامترهای ورودی مناسب و استفاده از ساختارهای مناسب شبکه عصبی مصنوعی و شبکه عصبی- فازی هستند. (Ghafari and Vafakhah (2013) با استفاده از شبکه‌های عصبی مصنوعی و فازی عصبی تطبیقی، اقدام به شبیه‌سازی فرآیند بارش- رواناب روزانه، در حوضه آبخیز حاجی قوشان نمودند. در این سیستم‌ها سه ترکیب مختلف ورودی شامل بارندگی همان روز، بارندگی همان روز و روز قبل، بارندگی همان روز و روز قبل و دو روز قبل از آن، مورد استفاده قرار گرفت. بر اساس نتایج ایشان، مدل ANFIS نسبت به مدل ANN فرآیند بارش- رواناب را با دقت بالاتری پیش‌بینی نمود. (Dehghani et al. (2010) جریان روزانه در حوضه آبخیز کسلیان با استفاده از شبکه عصبی مصنوعی و شبکه عصبی- فازی تطبیقی شبیه‌سازی نمودند. در این تحقیق از آمار بارش، تخییر و دما ایستگاه هواشناسی سنگده که ورودی مدل و آمار دبی ایستگاه ولیکین که خروجی مدل محسوب می‌شود طی سالهای ۱۳۸۲ تا ۱۳۸۸ استفاده شد. تعداد تأخیرهای لازم دو مدل ساختار بارش و تخییر با یک روز تأخیر برای مدل بهینه انتخاب شد. سپس نتایج با استفاده از نمایه‌های RMSE، برای ورود متغیرهای ورودی به شبکه‌ها با استفاده از نمودار خودهمبستگی جزئی به دست آمد. نتایج نشان داد که شبکه عصبی- فازی تطبیقی با تابع زنگوله‌ای شکل نسبت به مدل شبکه عصبی مصنوعی با همان ساختار با الگوریتم آموزشی در دوره آزمون توانایی بهتری برای مدل‌سازی بارش- رواناب در حوضه آبخیز کسلیان دارد. (Migueluez et al. (2009) با استفاده از شبکه‌های عصبی مصنوعی در ترکیب با الگوریتم ژنتیک، رواناب شهری را پیش‌بینی نمودند. در این مطالعه از تکنیک هوش مصنوعی برای مدل‌سازی بارش و تولید رواناب سطحی برای یک منطقه شهری استفاده شده است. نتایج کار آنها نشان داد که مدل‌سازی رواناب با استفاده از شبکه‌های عصبی مصنوعی و با مدل پیش‌خور (الگوریتم‌های آموزش شبکه‌های مدل پیش‌خور از شیب تابع کارایی برای تنظیم وزن‌ها و بایاس‌ها استفاده می‌کنند. این شیب با استفاده از تکنیکی به نام پس‌انتشار تعیین می‌شود. در محاسبات پس‌انتشار از قانون زنجیره‌ای در حساب دیفرانسیل برای محاسبه مشتق توابع استفاده می‌شود) نتایج رضایت‌بخشی داشته است. (Haghizadeh et al.

رواناب حاصل از بارش‌های جوی مهم‌ترین منبع تأمین آب در بیشتر مناطق ایران می‌باشند. با توجه به شرایط آب‌وهوایی خشک تا نیمه خشک کشور و همچنین بروز خشکسالی‌های اخیر و از طرفی افزایش سیلاب، بکارگیری روش‌های علمی جمع‌آوری و مهار آب‌های سطحی به منظور تأمین آب و جلوگیری از خسارات، روزبه‌روز اهمیت بیشتری پیدا می‌کند. بنابراین برآورد دقیق‌تر رواناب حاصل از بارندگی در حوضه‌های آبریز اهمیت زیادی دارد. آگاهی از توان طبیعی تولید رواناب در حوضه‌های آبریز یکی از نیازهای اساسی برای برنامه‌ریزی اصولی جهت بهره‌برداری بهینه از رواناب می‌باشد. از این رو مطالعه هیدرولوژیکی و شبیه‌سازی بارش- رواناب در حوضه‌های آبریز در علوم و مهندسی آب از اهمیت زیادی برخوردار است. از بین مدل‌های شبیه‌سازی فرآیند بارش- رواناب، مدل‌های بر مبنای پردازش داده‌ها کاربرد گسترده‌ای دارند. از معروف‌ترین و پرکاربردترین روش‌های موجود در این زمینه، شبکه‌های عصبی مصنوعی (ANN) هستند که به خصوص در دهه اخیر کاربرد فراوانی در برآورد متغیرها در مسائل مختلف داشته‌اند. امروزه سیستم‌های ترکیبی نظیر سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)، ترکیبی از دو روش شبکه عصبی مصنوعی و منطق فازی بوده که ابزاری توانمند برای مدل‌سازی سیستم‌های غیرخطی پیچیده می‌باشد. یکی از مراحل مهم و مؤثر بر دقت مدل‌های بر مبنای پردازش داده‌ها، انتخاب متغیرهای ورودی مناسب و مؤثر می‌باشد. روش‌های مختلفی جهت تعیین متغیرهای ورودی در مدل‌های بر مبنای پردازش داده‌ها وجود دارد. علی‌رغم وجود روش‌های جدید و کارآمدتر جهت تعیین متغیرهای ورودی مؤثر، تاکنون در اکثر تحقیقات انجام شده در داخل و حتی خارج از کشور از روش‌های قدیمی که دارای نقص در انتخاب متغیرهای ورودی مؤثر می‌باشند، استفاده می‌شود. از جمله روش‌های قدیمی، روش سعی و خطا بوده که کاربر در این روش ترکیبات مختلفی از متغیرهای ورودی را در نظر گرفته و سپس اقدام به تعیین ساختار بهینه شبکه‌های عصبی مصنوعی به ازای هر ترکیب از متغیرهای ورودی می‌نماید. مواردی از تحقیقاتی که از روش سعی و خطا جهت تعیین متغیرهای ورودی مؤثر استفاده شده، در ادامه ارائه می‌شوند. (Araghinejad and Karamouz (2005) با استفاده از مفهوم تولید مجموعه‌ای از پیش‌بینی‌ها (ESP) و تفکیک مدل‌سازی برای متغیرهای اقلیمی و هیدرولوژیکی، از مدل‌های مفهومی برای پیش‌بینی بلندمدت حجم جریان رودخانه زاینده رود در محل ورودی به سد زاینده‌رود استفاده کردند. نتایج این مدل با یک مدل پیش‌بینی ماهانه بر مبنای شبکه‌های عصبی که با استفاده از اطلاعات مشاهده شده، جریان ماهانه را پیش‌بینی می‌کند، مقایسه شد. نتایج نشان داد که رویکرد ارائه شده

الگوریتم PMI نشان داد که مدل توسعه یافته با الگوریتم PMI از دقت پیش‌بینی بیشتری همراه با صرفه‌جویی قابل توجه در توسعه مدل برخوردار است. علاوه بر این، نتایج بدست آمده از روش PMI برای آگاهی از روابط مهمی که بین متغیرهای سیستم توزیع آب وجود دارد، مفید می‌باشد. (Fang et al. (2018) به پیش‌بینی تبخیر- تعرق مرجع^۴ (ET₀) در مناطق کم توسعه یافته از لحاظ اقتصادی و با کمبود داده‌های هواشناسی شامل حوضه‌های رودخانه جینگ و بیولو در چین پرداختند. آنها ابتدا متغیرهای مؤثر ورودی با الگوریتم PMI مشخص کردند و با نتایج روش همبستگی خطی جزیی^۵ مقایسه کردند. همچنین ارتباط بین شاخص‌های اقلیمی جهانی و ET₀ منطقه‌ای نیز شناسایی شد. نتایج نشان داد که الگوریتم PMI بهتر از روش همبستگی خطی جزیی در حذف متغیرهای اضافی و دستیابی به تعداد متغیرهای پیش‌بینی‌کننده کمتر می‌باشد. تجزیه و تحلیل تلفیقی ارتباط بین ENSO⁶ و Nino1+2⁶ و ET₀ منطقه‌ای نشان‌دهنده تأثیر رویدادهای ENSO⁷ بر فرایند ET₀ در منطقه مورد مطالعه است. مقایسه عملکرد مدل نیز نشان داد که مدل‌های تصادفی غیرخطی (SVR⁸) یا RF⁹ با انتخاب ورودی از طریق PMI همیشه از مدل‌های خطی (MLR¹⁰) با ورودی تعیین شده با همبستگی خطی) برتر نیستند، ولی با توجه به نیاز به تعداد کمتر متغیرهای پیش‌بینی‌کننده، از لحاظ عملکرد کاملاً قابل مقایسه با مدل MLR هستند. بنابراین تعیین متغیرهای ورودی مدل با روش PMI و ترکیب شاخص‌های اقلیمی جهانی با ET₀ می‌تواند به توسعه مدل‌های پیش‌بینی ET₀ مناسب برای مناطق کمبود داده کمک کند. (Anusree and Varghese (2016) با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه و مدل فازی عصبی تطبیقی و روش رگرسیون چند متغیره، فرایند بارش- رواناب را به صورت روزانه در حوضه آبخیز کاروانور در هند شبیه‌سازی نمودند. نتایج نشان داد مدل ANFIS پیش‌بینی دبی را با دقت بالاتری انجام می‌دهد. (Chang et al. (2017) برای انتخاب ورودی‌های مدل‌های هوش مصنوعی برای مدل‌سازی بارش- رواناب از دو تکنیک تحلیل همبستگی بین ورودی و خروجی و مدل ترکیبی شاخص اطلاعات متقابل و تحلیل همبستگی استفاده کردند. ورودی‌های مدل ANFIS بدین ترتیب انتخاب شد و شبیه‌سازی بارش رواناب صورت گرفت. سپس نتایج رواناب با مدل هیدرولوژیکی HEC-HMS مقایسه شد. نتایج نشان داد مدل ANFIS که متغیرهای ورودی آن با مدل ترکیبی انتخاب شده است، دبی پیک را بهتر برآورد می‌کند. Lee et al. (2010) دو نوع مدل شبکه عصبی مصنوعی برای شبیه‌سازی و پیش‌بینی فرایند بارش- رواناب در مناطق کوچک استفاده کردند. بر اساس نتایج تحقیقات آنها مدل شبکه عصبی تابع پایه شعاعی^{۱۱} با استفاده از تابع گوسی که روند مشابهی با تابع پایه‌ای دارد، پایداری بهتری نسبت به مدل شبکه عصبی پس‌انتشار^{۱۲} دارد. با وجودی که

(2015) با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه و مدل فازی عصبی تطبیقی و روش رگرسیون چندمتغیره، فرایند بارش- رواناب را به صورت روزانه در حوضه آبخیز خرم‌آباد شبیه‌سازی نمودند. برای ورودی‌ها از ترکیب‌های مختلف از ورودی‌های بارندگی همان روز، یک روز قبل و دو روز قبل استفاده شد. نتایج نشان داد که مدل عصبی فازی تطبیقی عملکرد بهتری از شبکه عصبی مصنوعی پرسپترون چندلایه و مدل رگرسیون چندمتغیره دارد. Ghorbani et al. (2015) فرایند بارش- رواناب روزانه در حوضه آبریز بالیخ‌لوچای با استفاده از ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی، هیبرید موجک- ماشین بردار پشتیبان و هیبرید موجک- شبکه عصبی مورد مطالعه و مقایسه قرار داده اند. داده‌های بارش- رواناب روزانه در طول دوره آماری (۱۳۷۹-۱۳۸۷) برای آموزش و صحت‌سنجی مدل‌ها مورد استفاده قرار گرفت. در حالت کلی نتایج حاکی از دقت قابل قبول هر چهار روش می‌باشد. از لحاظ اولویت نیز مدل هیبرید موجک- شبکه عصبی با بیشترین دقت و کمترین خطا در اولویت اول و مدل‌های هیبرید موجک- ماشین بردار پشتیبان، شبکه عصبی مصنوعی و ماشین بردار پشتیبان بترتیب در اولویت‌های بعدی قرار گرفتند.

اخیراً بر اساس روش آماری، الگوریتم‌هایی جهت تعیین متغیرهای ورودی مؤثر در مدل‌های بر مبنای پردازش داده‌ها ارائه شده‌اند. تنها الگوریتم غیرخطی جهت تعیین متغیرهای ورودی مؤثر در مدل‌های بر مبنای پردازش داده‌ها، الگوریتم اطلاعات متقابل جزیی^۱ (PMI) می‌باشد. الگوریتم PMI از شدت روابط بین ورودی‌ها و خروجی‌ها و بین متغیرهای اضافی جهت انتخاب متغیرهای ورودی مؤثر استفاده می‌کند. (Bowden et al. (2005) دو روش شامل الگوریتم PMI و مدل ترکیبی الگوریتم ژنتیک شبکه عصبی رگرسیون کلی خودسازمان‌دهی^۲ (SOM-GAGRRN) را برای تعیین ورودی‌های مناسب در مدل شبکه عصبی مصنوعی پیشنهاد دادند و برای پیش‌بینی ۱۴ روز آینده شوری رودخانه Murray در جنوب استرالیا به کار بردند. نتایج این دو روش با دو روش به کاربرده شده در مطالعات قبلی در این رودخانه مقایسه شدند. نتایج مقایسه نشان داد که دو روش پیشنهاد شده موجب توسعه مدل‌های ANN با خطای کمتر نسبت به مدل‌های آموزش دیده با استفاده از روش‌های قبلی شدند. همچنین مطالعه آنها نشان داد که الگوریتم PMI از توانمندی بیشتری نسبت به SOM-GAGRRN در پیش‌بینی ۱۴ روز آینده شوری رودخانه برخوردار است. (May et al. (2008) الگوریتم انتخاب متغیر ورودی^۳ (IVS) غیرخطی PMI برای توسعه مدل‌های ANN در پیش‌بینی کیفیت آب در سیستم توزیع آب به کار بردند. مقایسه نتایج مدل ANN توسعه‌یافته با الگوریتم PMI با نتایج مدل ANN بدون بکارگیری

قرار نگرفته است. هدف از این تحقیق شبیه‌سازی پیوسته بارش- رواناب با شبکه‌های عصبی مصنوعی با انتخاب متغیرهای ورودی مؤثر با استفاده از الگوریتم PMI می‌باشد. همچنین تأثیر تفکیک داده‌ها به دو دسته روزهای بارانی و غیربارانی بر دقت شبکه عصبی مصنوعی در شبیه‌سازی پیوسته بارش- رواناب مورد ارزیابی قرار گرفته است.

۲- مواد و روش‌ها

۲-۱- معرفی منطقه مورد مطالعه

حوضه مارون با مساحت حدود ۲۸۲۴ کیلومتر مربع در مختصات جغرافیایی (۵۰° ۴۹') تا (۱۰° ۵۱') طول شرقی و (۳۰° ۳۰') تا (۳۱° ۲۰') عرض شمالی و در ارتفاعات شهرستان بهبهان در استان خوزستان واقع شده است. حوضه آبریز مارون توسط حوضه‌های آبریز رودخانه‌های زهره و کارون در استان خوزستان و کهگیلویه و بویراحمد احاطه گردیده است. بخش عمده حوضه آبریز رودخانه مارون را مناطق کوهستانی تشکیل می‌دهد. از این میان بخش‌های شمالی و شرقی به ترتیب نسبت به بخش‌های دیگر ارتفاع بیشتری دارند. شکل ۱ نقشه حوضه مارون و موقعیت ایستگاه‌های باران‌سنجی و هیدرومتری را نشان می‌دهد. به منظور شبیه‌سازی پیوسته فرایند بارش- رواناب در حوضه مارون، آمار بارش روزانه ایستگاه‌های باران‌سنجی ایدنک و الگن و آمار دبی روزانه ایستگاه هیدرومتری ایدنک متعلق به وزارت نیرو استفاده گردید. دوره زمانی مشترک سه ایستگاه از سال ۱۳۷۰-۲۱ تا سال ۱۳۹۲-۹۳ می‌باشد. جدول ۱ مشخصات آماری متغیرهای مورد استفاده را نشان می‌دهد.

۲-۲- تعیین متغیرهای ورودی مؤثر در مدل‌های بر مبنای پردازش داده‌ها

روش‌های مختلفی جهت تعیین متغیرهای ورودی در مدل‌های بر مبنای پردازش داده‌ها به‌ویژه شبکه‌های عصبی مصنوعی وجود دارند. این روش‌ها عبارتند از: روش سعی و خطا، روش اکتشافی، روش بر مبنای دانش کارشناسان، روش بر مبنای تحلیل آماری و روش ترکیبی از روش‌های مختلف (Bowden et al., 2005). روش سعی و خطا دو عیب عمده را شامل می‌شود: ۱- با توجه به اینکه ترکیبات زیادی از متغیرها، به عنوان ورودی در مدل‌های بر مبنای پردازش داده‌ها در نظر گرفته می‌شود، ولی هیچ تضمینی جهت انتخاب بهترین ترکیب از متغیرهای ورودی وجود ندارد. مخصوصاً برای مدل‌سازی پدیده‌هایی که شامل متغیرهای ورودی زیادی می‌باشند. ۲- با توجه به اینکه برای هر ترکیب از متغیرهای ورودی بایستی مدل‌های مختلف شبکه عصبی مصنوعی آموزش و آزمون شود، مدت زمان لازم و همچنین حجم

RBFNN نسبت به BPNN اعتبار بیشتری دارد اما میزان خطای RBFNN بیشتر از BPNN بدست آمد. (Tan et al., 2018) از روش ترکیبی تجزیه تجربی- گروهی^{۱۳} جهت انتخاب ورودی‌های مدل در پیش‌بینی رواناب با استفاده از شبکه‌های عصبی مصنوعی در حوضه رودخانه یانگ‌تسه استفاده کردند. نتایج نشان داد که این روش ترکیبی در فصول سیلابی نتایج بهتری را برای پیش‌بینی سیلاب نسبت به روش‌های دیگر هوش مصنوعی از قبیل ANN، SVM، ANFIS و ANFIS ارائه می‌کند. (Chang et al., 2018) یک مدل هوشمند ANFIS را برای شبیه‌سازی بارش- رواناب ارائه نمودند. بطوریکه انتخاب نحوه مدل‌سازی و توابع منطق فازی بصورت بسیار منعطف قابل تغییر است و می‌تواند نتایج مدل‌سازی را بهبود ببخشد. روش‌های هوشمند در شبیه‌سازی بارش- رواناب بسیار مورد توجه قرار گرفته‌اند و تحقیقات مختلفی در خارج و داخل کشور انجام شده است (El-Shafie et al., 2011; Kisi, 2010; Dastorani et al., 2011; Khaleghi et al., 2010; Kurtulus and Razack, 2010; Nabizadeh et al., 2012; Nourani et al., 2009; Salajegheh et al., 2009; Toker and Markus, 2000; Zareazadeh-Mehrizi and Bozorghadad, 2010; Shahverdi and Samani, 2010; Dehghani et al., 2010).

بنابراین با توجه به ارزیابی و مقایسات انجام شده بین الگوریتم PMI و روش‌های دیگر، الگوریتم PMI از توانایی و دقت بیشتری برای انتخاب متغیرهای ورودی مؤثر در مدل‌سازی سیستم‌های پیچیده و غیرخطی برخوردار بوده است. بررسی مقالات در زمینه به‌کارگیری روش‌های هوش مصنوعی در داخل کشور نشان می‌دهد که در اکثر مقالات از روش سعی و خطا جهت تعیین بهترین ترکیب متغیرهای ورودی استفاده شده است (Dastourani et al., 2011; Ghafari and Vafakhah, 2013; Haghizadeh et al., 2016). روش سعی و خطا دو عیب عمده شامل می‌شوند: اولاً، با توجه به اینکه ترکیبات زیادی از متغیرها، به عنوان ورودی در مدل‌های بر مبنای پردازش داده‌ها در نظر گرفته می‌شود، هیچ تضمینی جهت انتخاب بهترین ترکیب از متغیرهای ورودی وجود ندارد. دوماً، با توجه به اینکه برای هر ترکیب از متغیرهای ورودی بایستی مدل‌های مختلف شبکه عصبی مصنوعی آموزش و آزمون شود، مدت زمان لازم و حجم محاسبات بسیار زیاد است. علاوه بر این همانطور که در متن مقدمه اشاره شده، از الگوریتم PMI فقط در زمینه‌های پیش‌بینی شوری جریان رودخانه، پیش‌بینی کیفیت آب در سیستم توزیع آب، پیش‌بینی تبخیر- ترقق مرجع (ET₀) و شبیه‌سازی تک‌واقع بارش- رواناب استفاده شده (Bowden et al., 2005; May et al., 2008; Chang et al., 2017; Fang et al., 2018) است، ولی تاکنون در زمینه شبیه‌سازی پیوسته بارش- رواناب در حوضه آبریز مورد استفاده




Fig. 1- Maroun basin and location of raingauges and hydrometric stations

شکل ۱- نقشه حوزه مارون و موقعیت ایستگاه‌های باران سنجی و هیدرومتری

Table 1- Statistical criteria for selected variables

جدول ۱- معیارهای آماری متغیرهای مورد استفاده

Statistical criteria	Idanak rainfall (mm)	Algan rainfall (mm)	Idanak streamflow (cms)
Maximum	138	221	2714
Minimum	0	0	1.97
Standard deviation	7.75	11.45	96.92
Average	1.66	2.79	52.80
Variation coefficient	4.68	4.10	1.84
Variation range	138	221	2712.03

انتخاب تمام متغیرهای ورودی شروع شده و به طور متوالی متغیرهای ورودی که عملکرد مدل را کاهش می‌دهند، حذف می‌شوند. عیب اصلی روش‌های اکتشافی آن است که همانند روش سعی و خطا هیچ تضمینی جهت انتخاب بهترین ترکیب متغیرهای ورودی وجود ندارد. عیب دیگر آنها این است که از لحاظ محاسبات بسیار سنگین می‌باشند. در روش بر مبنای دانش کارشناسان، از تجربیات و نتایج محققین دیگر جهت تعیین مجموعه اولیه متغیرهای ورودی استفاده می‌شود. این روش توسط کمیته جامعه مهندسان عمران آمریکا (ASCE) به منظور کاربرد ANN در مطالعات مربوط به هیدرولوژی تأیید شده است

محاسبات در این روش بسیار زیاد است. در روش اکتشافی متغیرهای ورودی به صورت مرحله‌ای (گام به گام) انتخاب می‌شوند. این روش اغلب به منظور اجتناب از در نظر گرفتن تمام زیرمجموعه‌های مربوط به متغیرهای ورودی به کار برده می‌شود. دو روش گام به گام استاندارد عبارتند از انتخاب رو به جلو و انتخاب رو به عقب. روش رو به جلو کاربرد بیشتری نسبت به روش رو به عقب دارد. در روش رو به جلو در هر مرحله متوالی با یک مجموعه متغیرهای ورودی انتخاب شده، متغیری که عملکرد مدل را بهبود می‌بخشد، بعنوان بهترین متغیر ورودی به مدل نهایی اضافه می‌شود. در روش رو به عقب، برنامه با

یک مشاهده y که عضوی از Y می‌باشد، وجود دارد که می‌توان آن را با توجه به آنتروپی شانون^{۱۶} H (Shannon, 1948) تعریف کرد. ولی با فرض یک متغیر ورودی تصادفی X که Y وابسته به آن است، مشاهدات متقابل (x, y) این عدم قطعیت را کاهش می‌دهد، زیرا اطلاع از x ، اجازه می‌دهد تا مقدار y استنتاج شود و برعکس. بنا به تعریف اطلاعات متقابل $I(X; Y)$ کاهش در عدم قطعیت متغیر Y به دلیل مشاهده X است (Cover and Thomas, 1991). این مسأله بصورت یک قسمت مشترک بین دو دایره در شکل ۲ نمایش داده شده است. این قسمت مشترک جایی است که عدم قطعیت کاهش یافته حول X و Y به ترتیب توسط آنتروپی شرطی $H(X|Y)$ و $H(Y|X)$ مشخص شده است. اطلاعات متقابل (MI) را می‌توان با فرمول زیر بصورت مستقیم محاسبه کرد (May et al., 2008):

$$I(X; Y) = \iint p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy \quad (۱)$$

$p(x)$ و $p(y)$ به ترتیب توابع چگالی احتمال حاشیه‌ای^{۱۷} X و Y هستند و $p(x, y)$ تابع چگالی احتمال توأم^{۱۸} است. به‌هرحال بصورت عملی، فرم صحیح توابع چگالی احتمال در رابطه (۱) مجهول است. از این‌رو، از برآورد چگالی‌های احتمال بجای آن استفاده می‌شود. با جایگذاری برآوردهای چگالی احتمال با تقریب عددی انتگرال در رابطه (۱) خواهیم داشت (May et al., 2008):

$$I(X; Y) \approx \frac{1}{n} \sum_{i=1}^n \log \left[\frac{f(x_i, y_i)}{f(x_i)f(y_i)} \right] \quad (۲)$$

که در آن f نمایانگر چگالی برآورد شده بر مبنای نمونه‌ای از n مشاهده از (x, y) است. از میناهای مختلفی برای لگاریتم در رابطه (۲) می‌توان استفاده کرد ولی معمولاً از \log_e یا e استفاده می‌شود. اگر مبنای لگاریتم مشخص نشده باشد، لگاریتم طبیعی در نظر گرفته می‌شود. با فرض رابطه (۲) می‌توان گفت که برآورد دقیق و مؤثر MI (اطلاعات متقابل) بستگی زیادی به روش بکار گرفته شده در برآورد توابع چگالی احتمال حاشیه‌ای و توأم دارد.

در مجموع سه معیار توقف الگوریتم PMI وجود دارد که عبارتند از: ۱- مقادیر بحرانی جدول‌بندی شده^{۲۰}، ۲- معیار بر مبنای اطلاعات اکائیکه^{۲۱} (AIC) (Akaike, 1974)، ۳- معیار آزمون همپل^{۲۲}. جداول مقادیر بحرانی ضریب همبستگی (R) به سهولت در دسترس هستند، که بر پایه فرمول تحلیلی برای توزیع خطای یک تخمین برای اندازه نمونه فرض شده استوار است. در مورد ضریب همبستگی خطی (R)، توزیع تخمین نمونه از یک توزیع t پیروی می‌کند. جداول مقادیر بحرانی ضریب همبستگی (R) بر پایه توزیع t ، به سادگی ساخته شده‌اند (David, 1966)، که مقدار بحرانی برای R برای تعداد نمونه‌ها و یک سطح اعتماد معین را تهیه می‌کنند. با این حال برخلاف ضریب همبستگی خطی، یک تعریف تحلیلی معادل برای I را نمی‌توان بر طبق

(Sharma, 2000). درک کامل از سیستم هیدرولوژیکی که قرار است مدل‌سازی شود به منظور انتخاب مناسب متغیرهای ورودی، مهم می‌باشد. اگر متغیرهای ورودی مؤثر انتخاب نشوند ممکن است بعضی اطلاعات در مورد سیستم از دست برود. به عبارتی اگر متغیرهای ورودی نادرست در نظر گرفته شوند ممکن است موجب سردرگمی در فرایند آموزش مدل ANN شود. در روش ترکیبی از روش‌های مختلف، روش‌های مختلف فوق‌الذکر جهت تعیین متغیرهای ورودی در مدل‌سازی سیستم مورد مطالعه با مدل‌های ANN به کار برده می‌شوند. سپس متغیرهای ورودی نهایی از ترکیب نتایج روش‌های مختلف مشخص می‌گردد. با توجه به اینکه هر یک از این روش‌ها دارای ضعف برای تعیین متغیرهای ورودی مؤثر می‌باشند، بنابراین روش ترکیبی نیز دارای نقص در انتخاب متغیرهای ورودی مؤثر می‌باشد. روش آماری روش مناسبی برای تعیین متغیرهای ورودی مؤثر است، به طوری که به کاربرد خاصی محدود نیست. بنابراین پتانسیل خوبی برای ارائه الگوریتم‌های مناسب که به عنوان یک مؤلفه به ساختار مدل‌های ANN اضافه شوند، وجود دارد. الگوریتمی که بر تحلیل داده‌ها استوار می‌باشد و نه به دانش کارشناسان یا روش اکتشافی. تنها الگوریتم غیرخطی انتخاب متغیرهای ورودی جهت تعیین متغیرهای ورودی مؤثر در مدل‌های بر مبنای پردازش داده‌ها، الگوریتم PMI می‌باشد. در ادامه به اختصار الگوریتم PMI معرفی می‌گردد.

۲-۲-۱- معرفی الگوریتم PMI بر پایه انتخاب ورودی (PMIS)

الگوریتم انتخاب ورودی بر مبنای PMI (PMIS) معرفی شده در این مقاله، در ابتدا توسط Sharma (2000) جهت شناسایی متغیرهای ورودی مؤثر در مدل‌های هیدرولوژیکی توسعه داده شد. الگوریتم PMI هر تکرار را با در نظر گرفتن یک ورودی (C) و یک خروجی (Y) و با پیدا کردن C_S (فرض می‌شود که C_S متفاوت از C است) که مقدار PMI را با توجه به متغیر خروجی ماکزیمم می‌کند (با توجه به ورودی‌هایی که از قبل انتخاب شده‌اند)، انجام می‌دهد. مفهوم آماری که PMI برای C_S برآورد می‌کند بر مبنای محدوده‌های اطمینان^{۱۴} است که از توزیع تشکیل شده توسط یک حلقه‌ی خودراه‌انداز^{۱۵}، تعیین شده است. اگر ورودی معنی‌دار باشد، C_S به S (مجموعه متغیرهای ورودی انتخاب شده) اضافه شده و انتخاب کردن ادامه می‌یابد، تا جایی که هیچ ورودی معنی‌داری باقی نماند، سپس متعاقباً الگوریتم متوقف می‌شود.

۲-۲-۲- برآورد اطلاعات متقابل جزئی (PMI)

با توجه به یک متغیر خروجی تصادفی Y ، مقداری عدم قطعیت در مورد

که مقداری بین ۵۰ تا ۵۰۰۰ دارد) که این محاسبه برای بدست آوردن داده‌هایی با مقادیر بحرانی استفاده می‌شود که این داده‌ها می‌تواند برای آزمون مستقل بودن بر مبنای MI بکار گرفته شود.

برای هر اندازه نمونه، ابتدا یک سری $\varepsilon_y \sim N(0,1)$ ساخته می‌شود و سپس توابع چگالی احتمال حاشیه‌ای f_{ε_y} محاسبه می‌شود. مجموع یکصد هزار تکرار از سری $\varepsilon_x \sim N(0,1)$ ، مستقل از $\varepsilon_y \sim N(0,1)$ تولید می‌شود. برای هر نمونه از ε_x ، توابع چگالی احتمال حاشیه‌ای f_{ε_x} و $f_{\varepsilon_x \varepsilon_y}$ تخمین زده و متعاقباً $\hat{I}(\varepsilon_x \varepsilon_y)$ ارزیابی می‌شود. نتایج مقادیر بحرانی I در جدول ۲ برای سطوح اعتماد مختلف درج شده است. دو ضابطه جایگزین متوقف‌کننده فرمول‌بندی شده که بوسیله آن در هر تکرار، I'CsY.S با مقادیر بحرانی مربوطه $Ib(95)$ و $Ib(99)$ که از جدول ۲ بدست‌آمده مقایسه می‌شود، که از این دو معیار بجای محاسبات مستقیم از سیستم خودراه‌انداز، جهت تعیین اینکه کدام متغیر باید انتخاب شود یا اینکه الگوریتم متوقف شود، استفاده می‌شود. حذف محاسباتی حلقه سیستم خودراه‌انداز باعث می‌شود تا انتخاب متغیرهای ورودی بسیار سریعتر انجام شود (May et al., 2008).

۲-۲-۳- معیار آزمون همپیل (Z)

روش‌های تعیین داده پرت، بعنوان یک روش آماری قوی برای تعیین این که آیا یک مقدار x موردنظر، بطور قابل توجهی متفاوت از مقادیر دیگر در مجموعه‌ای از مقادیر X است. این آزمون انحراف یک مشاهده منفرد را نسبت به میانگین تمامی مشاهدات مقایسه می‌کند. یک مقدار مشاهده‌ای با داشتن امتیاز Z بزرگتر از ۳ بر اساس قانون 3σ برای توزیع نرمال معمولاً بعنوان داده پرت در نظر گرفته می‌شود (داده‌های پرت دارای مقداری بیشتر از ۳ برابر انحراف معیار از میانگین مجموعه داده‌ها دارند). در فرمول‌بندی کردن یک ضابطه متوقف‌کننده بر پایه تشخیص داده‌های پرت برای الگوریتم PMIS، فرض اساسی بر این است که مجموعه داده‌ها ابتدا دارای برخی متغیرهای اضافی و غیروابسته بوده و متغیرهای مهم شناسایی خواهند شد.




Fig. 2- Venn diagram, relation between MI and entropy for Y as output and X as Input (May et al., 2008)

شکل ۲- دیاگرام وین^{۱۹}، نشان‌دهنده رابطه بین اطلاعات متقابل (MI) و آنتروپی برای خروجی Y و متغیر ورودی منفرد X (May et al., 2008)

رابطه (۲) نتیجه‌گیری کرد (Goebel et al., 2005). از این رو محققان باید از خودراه‌انداز کردن، برای محاسبه $f(\hat{I})$ کمک بگیرند (Granger et al., 2004; Sharma, 2000). در همین راستا، تحقیقی توسط Granger et al. (2004) انجام شده، که توزیع تخمین‌گر اطلاعات بر مبنای هسته \hat{p} ، برای تعدادی از مدل‌های سری زمانی مورد بررسی قرار گرفت که در نهایت یک جایگزین عملی برای سیستم خودراه‌انداز پیشنهاد شد.

به جای استفاده از مقادیر تحلیلی، یک روش برای ساختن جداول مقادیر بحرانی محاسبه شده برای \hat{I} استفاده از شبیه‌سازی مونت کارلو که توسط May et al. (2006) شرح داده شده، می‌باشد. شبیه‌سازی مونت کارلو برای تعیین عملی توزیع تخمین‌گر MI که در گام اول در توسعه یک معیار متوقف‌کننده بر مبنای مقادیر بحرانی تقریبی، به کار گرفته شد. در هر شبیه‌سازی، MI برای یک سری داده‌ها در مقایسه با داده‌های نویز-سفید^{۲۳} گوسین محاسبه می‌شود (با اندازه نمونه n،

Table 2- Critical values of the KDE-based Mutual Information estimator (May et al., 2006)
جدول ۲- مقادیر بحرانی تخمین‌گر اطلاعات متقابل بر مبنای برآورد چگالی هسته^{۲۴} (KDE) (May et al., 2006)

n	\bar{I}	$f^{(90)}$	$f^{(95)}$	$f^{(99)}$	n	\bar{I}	$f^{(90)}$	$f^{(95)}$	$f^{(99)}$	n	\bar{I}	$f^{(90)}$	$f^{(95)}$	$f^{(99)}$
50	0.1323	0.1990	0.2224	0.2705	180	0.0798	0.1072	0.1166	0.1356	600	0.0473	0.0589	0.0627	0.0702
60	0.1236	0.1825	0.2031	0.2452	200	0.0763	0.1019	0.1103	0.1276	700	0.0441	0.0544	0.0578	0.0644
70	0.1166	0.1694	0.1879	0.2254	220	0.0735	0.0975	0.1055	0.1215	800	0.0415	0.0509	0.0539	0.0597
80	0.1106	0.1592	0.1756	0.2091	240	0.0707	0.0932	0.1005	0.1158	900	0.0393	0.0479	0.0507	0.0563
90	0.1057	0.1506	0.1657	0.1973	260	0.0682	0.0894	0.0965	0.1108	1000	0.0375	0.0455	0.0481	0.0531
100	0.1013	0.1429	0.1572	0.1858	280	0.0661	0.0862	0.0928	0.1062	2000	0.0270	0.0318	0.0333	0.0361
120	0.0943	0.1309	0.1434	0.1688	300	0.0642	0.0834	0.0896	0.1022	3000	0.0222	0.0257	0.0268	0.0289
140	0.0883	0.1211	0.1321	0.1546	400	0.0567	0.0724	0.0775	0.0876	4000	0.0192	0.0221	0.0230	0.0247
160	0.0839	0.1138	0.1237	0.1444	500	0.0513	0.0646	0.0689	0.0775	5000	0.0172	0.0196	0.0204	0.0218

نظر گرفته شد. جهت تهیه مجموعه پتانسیل متغیرهای ورودی، هر یک از متغیرهای ورودی شامل بارش روزانه ایدنک و بارش روزانه الگن نیز تا یک هفته قبل در نظر گرفته شد. همچنین با توجه به اینکه مقدار دبی در یک ایستگاه هیدرومتری وابسته به مقدار دبی در روزهای قبل می‌باشد، تأخیر زمانی یک هفته‌ای برای مقدار دبی در ایستگاه هیدرومتری ایدنک در نظر گرفته شد تا مجموعه پتانسیل متغیرهای ورودی در شبکه عصبی مصنوعی بدست آید. سپس متغیرهای ورودی مؤثر بر متغیر خروجی (دبی در زمان حال در ایستگاه هیدرومتری ایدنک) با استفاده از الگوریتم PMI بدست آمد. بعد از آماده‌سازی داده‌ها و انتخاب دوره زمانی مشترک بین متغیرها و اعمال تأخیر زمانی جهت ساخت مجموعه پتانسیل متغیرهای ورودی، کل الگوهای آموزشی برابر با ۸۳۹۴ الگو بدست آمد. از این تعداد کل الگوهای آموزشی، ۶۵٪ الگوها (۵۴۷۲ الگو) به منظور آموزش (واسنجی) شبکه‌های عصبی مصنوعی و ۳۵٪ الگوها (۲۹۲۲ الگو) جهت آزمون (اعتبارسنجی) شبکه‌های عصبی مصنوعی استفاده گردید. بنابراین به منظور آموزش شبکه‌های عصبی مصنوعی داده‌های از تاریخ ۱۳۷۰/۷/۸ تا ۱۳۸۵/۶/۳۱ و جهت آزمون شبکه‌های عصبی مصنوعی داده‌های از تاریخ ۱۳۸۵/۷/۱ تا ۱۳۹۳/۶/۳۱ در نظر گرفته شد. جدول ۳ مجموعه پتانسیل متغیرهای ورودی و خروجی حاصل از ساخت الگوهای آموزشی برای مدل بارش- رواناب تک‌ضابطه‌ای را نشان می‌دهد. همچنین مجموعه پتانسیل متغیرهای ورودی و خروجی برای مدل بارش- رواناب دوضابطه‌ای (بخش مربوط به روزهای بارانی) در جدول ۴ نشان داده شده است. علاوه بر این برای مدل بارش- رواناب دوضابطه‌ای (بخش مربوط به روزهای غیربارانی)، مجموعه پتانسیل متغیرهای ورودی و خروجی در جدول ۵ نشان داده شده است. همانطوری که در جداول ۳، ۴ و ۵ نشان داده شده، تنها متغیر خروجی دبی جریان در ایستگاه هیدرومتری ایدنک در زمان حال می‌باشد.

به منظور تعیین پارامترهای مؤثر بر متغیر خروجی (دبی جریان در ایستگاه هیدرومتری ایدنک)، از الگوریتم PMI استفاده شد. این الگوریتم که بصورت یک افزونه^{۲۶} به نرم‌افزار اکسل ۲۰۰۷ و بالاتر، اضافه می‌شود با محاسبه مقدار PMI، متغیرهای ورودی مؤثر را مشخص می‌سازد. لازم به ذکر است که این الگوریتم به صورت پیش‌فرض در نظر می‌گیرد که متغیرهای ورودی دارای چولگی صفر هستند و از یک توزیع نرمال پیروی می‌کنند. در همین راستا برای استفاده از این الگوریتم بایستی ابتدا داده‌ها را نرمال کرد. جهت نرمال‌سازی داده‌های بارش در ایستگاه بارانسنجی ایدنک و الگن، تمام مقادیر بارش به توان یک عدد کوچک (۰/۰۰۱) رسانده شد. جهت نرمال‌سازی داده‌های دبی جریان در ایدنک، از تبدیل لگاریتمی استفاده گردید و داده‌ها بصورت تبدیل شده به الگوریتم معرفی شدند.

با این وجود، پنهان‌شدن داده‌های پرت از اهمیت زیادی برخوردار است، زیرا احتمال دارد که مجموعه داده‌ها دارای بیش از یک متغیر وابسته باشد. از این‌رو، یک مقدار Z اصلاح شده، که از فاصله همپل استفاده می‌کند، بجای افزایش کارایی روش بکارگرفته شده است. فاصله همپل (Davies and Gather, 1993) بر پایه میانه مجموعه ورودی‌ها بنا نهاده شده است. نقطه از کارافتادگی آزمون همپل $n/2$ است و بعنوان یکی از توانمندترین آزمون‌های تشخیص داده پرت در صورت وجود چندین داده پرت شناخته می‌شود (Davies and Gather, 1993; Pearson, 2002). آزمون همپل با محاسبه انحراف مطلق از میانه PMI برای همه ورودی‌ها بصورت زیر شروع می‌شود (May et al., 2008):

$$d_j = |I_{C_j Y.S} - I_{C_j Y.S}^{(50)}| \quad (4)$$

که در این رابطه d_j نمایانگر انحراف مطلق، $I_{C_j Y.S}$ برابر با مقدار PMI برای متغیر x و $I_{C_j Y.S}^{(50)}$ نشان‌دهنده میانه PMI برای مجموعه ورودی‌های C می‌باشد. سپس فاصله همپل را می‌توان بصورت زیر تعیین کرد (May et al., 2008):

$$Z_j = \frac{d_j}{1.4826d_j^{(50)}} \quad (5)$$

که Z_j نشان دهنده فاصله همپل برای مجموعه ورودی C_j و $d_j^{(50)}$ نشان‌دهنده میانه انحراف مطلق^{۲۵} (MAD)، d_j می‌باشد. ضریب $1/4826$ فاصله را بنحوی تغییر می‌دهد که قانون $Z > 3$ را بتوان اعمال کرد، همانطوری که در مورد Z-test متعارف بکار برده شده است (Pearson, 2002). با استفاده از این معیار متوقف‌کننده، الگوریتم PMI برپایه انتخاب ورودی، دیگر حاوی حلقه خودراه‌انداز نیست، و نیز PMI با هیچ مقدار بحرانی از I مقایسه نمی‌شود. در عوض، مقدار Z_s برای برگزیدن C_s تعیین می‌شود و اگر $Z_s > 3$ باشد، ورودی انتخاب و به S اضافه می‌شود، در غیر این صورت ادامه عملیات الگوریتم انتخاب متغیرهای ورودی متوقف می‌شود.

به منظور شبیه‌سازی پیوسته فرایند بارش- رواناب در حوضه مارون، مدل بارش- رواناب بصورت تک‌ضابطه‌ای و دوضابطه‌ای با استفاده از شبکه‌های عصبی مصنوعی تهیه گردید. در مدل تک‌ضابطه‌ای، تمام مقادیر بارش بدون تفکیک آنها به روزهای بارانی و غیربارانی مورد استفاده قرار گرفت. یک مدل بارش- رواناب دو ضابطه‌ای شامل یک مدل مربوط به روزهای بارانی و یک مدل مربوط به روزهای غیربارانی است. جهت تفکیک داده‌ها به دو بخش روزهای بارانی و غیربارانی، روزهایی که در آنها مجموع مقادیر بارش در دو ایستگاه ایدنک و الگن برابر و یا بزرگتر از یک میلیمتر بود بعنوان روزهای بارانی در نظر گرفته شد. همچنین روزهایی که در آنها مجموع مقادیر بارش در دو ایستگاه ایدنک و الگن کمتر از یک میلیمتر بود بعنوان روزهای غیربارانی در

Table 3- The potential set of input and output variables resulting from the forming of training patterns for single criterion rainfall-runoff model

جدول ۳- مجموعه پتانسیل متغیرهای ورودی و خروجی حاصل از ساخت الگوهای آموزشی برای مدل تک ضابطه‌ای بارش- رواناب

Variable name	Variable	Variable Type
Ridanak(t)	Idanak present rainfall	Input
Ridanak(t-1)	Idanak past day rainfall	Input
Ridanak(t-2)	Idanak 2 past day rainfall	Input
Ridanak(t-3)	Idanak 3 past day rainfall	Input
Ridanak(t-4)	Idanak 4 past day rainfall	Input
Ridanak(t-5)	Idanak 5 past day rainfall	Input
Ridanak(t-6)	Idanak 6 past day rainfall	Input
Ridanak(t-7)	Idanak 7 past day rainfall	Input
RAlgan(t)	Algan present rainfall	Input
RAlgan(t-1)	Algan past day rainfall	Input
RAlgan(t-2)	Algan 2 past day rainfall	Input
RAlgan(t-3)	Algan 3 past day rainfall	Input
RAlgan(t-4)	Algan 4 past day rainfall	Input
RAlgan(t-5)	Algan 5 past day rainfall	Input
RAlgan(t-6)	Algan 6 past day rainfall	Input
RAlgan(t-7)	Algan 7 past day rainfall	Input
QIdanak(t-1)	Idanak past day discharge	Input
QIdanak(t-2)	Idanak 2 past day discharge	Input
QIdanak(t-3)	Idanak 3 past day discharge	Input
QIdanak(t-4)	Idanak 4 past day discharge	Input
QIdanak(t-5)	Idanak 5 past day discharge	Input
QIdanak(t-6)	Idanak 6 past day discharge	Input
QIdanak(t-7)	Idanak 7 past day discharge	Input
QIdanak(t)	Idanak present discharge	Output

Table 4- The Potential set of Input and Output Variables of the dual criteria rainfall-runoff model for rainy days

جدول ۴- مجموعه پتانسیل متغیرهای ورودی و خروجی مدل دو ضابطه‌ای بارش- رواناب بخش مربوط به روزهای بارانی

Variable name	Variable	Variable Type
Ridanak(t)	Idanak present rainfall	Input
Ridanak(t-1)	Idanak past day rainfall	Input
Ridanak(t-2)	Idanak 2 past day rainfall	Input
Ridanak(t-3)	Idanak 3 past day rainfall	Input
Ridanak(t-4)	Idanak 4 past day rainfall	Input
Ridanak(t-5)	Idanak 5 past day rainfall	Input
Ridanak(t-6)	Idanak 6 past day rainfall	Input
Ridanak(t-7)	Idanak 7 past day rainfall	Input
RAlgan(t)	Algan present rainfall	Input
RAlgan(t-1)	Algan past day rainfall	Input
RAlgan(t-2)	Algan 2 past day rainfall	Input
RAlgan(t-3)	Algan 3 past day rainfall	Input
RAlgan(t-4)	Algan 4 past day rainfall	Input
RAlgan(t-5)	Algan 5 past day rainfall	Input
RAlgan(t-6)	Algan 6 past day rainfall	Input
RAlgan(t-7)	Algan 7 past day rainfall	Input
QIdanak(t)	Idanak present discharge	Output

Table 5- Potential set of input and output variables of the dual criteria rainfall-runoff model for non-rainy days

جدول ۵- مجموعه پتانسیل متغیرهای ورودی و خروجی مدل دوضابطه‌ای بارش- رواناب بخش مربوط به روزهای غیربارانی

Variable name	Variable	Variable Type
QIdanak(t-1)	Idanak past day discharge	Input
QIdanak(t-2)	Idanak 2 past day discharge	Input
QIdanak(t-3)	Idanak 3 past day discharge	Input
QIdanak(t-4)	Idanak 4 past day discharge	Input
QIdanak(t-5)	Idanak 5 past day discharge	Input
QIdanak(t-6)	Idanak 6 past day discharge	Input
QIdanak(t-7)	Idanak 7 past day discharge	Input
QIdanak(t)	Idanak present discharge	Output

این شبکه نرون‌های هر لایه تماماً به نرون‌های لایه قبل متصل شده است. خروجی هر لایه پس از تأثیر گذاشتن تابع محرک، ورودی لایه بعدی می‌گردد و این روند تا بدست آمدن خروجی شبکه ادامه می‌یابد.

۲-۳-۱- شبکه‌های RBF

شبکه‌های RBF نوعی شبکه عصبی پیش‌خور بوده که ساختار آنها شبیه شبکه‌های MLP هست. شبکه‌های RBF نیازمند نرون‌های بیشتری نسبت به شبکه‌های استاندارد پیش‌خور با الگوریتم پس انتشار خطا می‌باشند ولی این شبکه‌ها را می‌توان در زمانی کوتاه‌تر نسبت به شبکه‌های پیش‌خور آموزش داد (Kalra et al., 2005). این نوع شبکه الگوی ورودی n بعدی را با استفاده از گره‌های واقع در لایه مجاور به یک الگوی خروجی z بعدی نگاشت می‌کند. لایه ورودی مقادیر ورودی را به هر یک از گره‌های لایه پنهان ارسال می‌کند.

۲-۳-۳- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی جزء سیستم‌های دینامیکی هوشمند مدل-آزاد بوده که مبتنی بر داده‌های تجربی بوده و با پردازش روی این داده‌ها دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. این سامانه‌ها از دو ویژگی اساسی یادگیری یا نگاشت‌پذیری بر اساس آرایه‌ی داده‌های تجربی (قابلیت تعمیم‌پذیری) و ساختارپذیری موازی برخوردارند که ضمن اجرای فرایند آموزش، اطلاعات مربوط به داده‌ها درون وزنهای شبکه ذخیره می‌شوند. شبکه‌های MLP از چندلایه تشکیل می‌شوند که هر لایه، ورودی لایه بعدی را بصورت پیش‌خور تولید می‌کند. ساختار یک شبکه MLP با تعیین تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، تابع انتقال الگوریتم آموزش، روش تصحیح وزن‌ها و نوع مدل تعیین می‌شود (Kisi, 2007). شکل ۳ بیانگر شبکه پرسپترون یک لایه می‌باشد.




Fig. 3- One layer perceptron network (Bowden et al., 2005)

شکل ۳- شبکه پرسپترون یک لایه (MLP) (Bowden et al., 2005)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{S_i - O_i}{O_i} \right| * 100 \quad (10)$$

$$PTVE = \frac{\sum_{i=1}^n S_i - \sum_{i=1}^n O_i}{\sum_{i=1}^n O_i} * 100 \quad (11)$$

۳- نتایج و بحث

جدول ۶ نتایج الگوریتم PMI برای ۶ متغیر مؤثر به ترتیب اولویت برای مدل تک‌ضابطه‌ای را نشان می‌دهد. همچنین جدول ۷ نتایج الگوریتم PMI برای مدل دوضابطه‌ای بارش- رواناب بخش مربوط به روزهای بارانی را نشان می‌دهد. علاوه بر این نتایج الگوریتم PMI برای مدل دوضابطه‌ای بخش مربوط به روزهای غیربارانی در جدول ۸ نشان داده شده است. در جداول ۶ الی ۸ Iteration تعداد تکرار الگوریتم PMI، Variable نام متغیر، مقدار اطلاعات متقابل جزئی (PMI) برای هر متغیر، MC-I*(95) محدوده ۹۵ درصد مقدار بحرانی اطلاعات متقابل (MI)، MC-I*(99) محدوده ۹۹ درصد مقدار بحرانی MI و Hampel مقدار فاصله همپل برای هر متغیر است. برای تعیین متغیرهای ورودی مؤثر با توجه به مقادیر ضابطه همپل، تا متغیرهایی مؤثر هستند که مقدار فاصله همپل آنها بزرگتر از ۳ باشند. البته معمولاً برای سخت‌گیری کمتر، مقدار فاصله همپل بزرگتر از ۲ در نظر گرفته می‌شود. بنابراین در جدول ۶ متغیرهایی مؤثر بر دبی جریان در ایستگاه ایدنک در مدل تک ضابطه‌ای بارش- رواناب عبارتند از دبی جریان یک روز قبل و دو روز قبل در ایستگاه ایدنک. با توجه به مقدار معیار همپل در جدول ۷ که مربوط به مدل دوضابطه‌ای بخش مربوط به روزهای بارانی می‌باشد، متغیرهای ورودی مؤثر بر دبی جریان در ایستگاه ایدنک به ترتیب عبارتند از بارش یک روز قبل ایستگاه ایدنک، بارش یک روز قبل در ایستگاه الگن، بارش دو روز قبل ایدنک و بارش در زمان حال الگن. همچنین با توجه به معیار همپل در جدول ۸ متغیرهای ورودی مؤثر بر دبی جریان در ایدنک مربوط به مدل دوضابطه‌ای بخش مربوط به روزهای غیربارانی عبارتند از دبی جریان یک روز قبل و دو روز قبل در ایستگاه ایدنک.

۳-۱- تعیین بهترین ساختار مدل تک‌ضابطه‌ای و دوضابطه‌ای بارش- رواناب شبکه‌های عصبی مصنوعی

به منظور تعیین بهترین ساختار مدل تک‌ضابطه‌ای و دوضابطه‌ای بارش- رواناب شبکه‌های عصبی مصنوعی، شبکه‌های عصبی مصنوعی MLP و RBF با ساختارهای مختلف از لحاظ تعداد لایه‌های میانی، نوع الگوریتم آموزش شبکه، نوع تابع انتقال، تعداد نرون‌های لایه میانی و تعداد تکرارهای (Epoch) آموزش در نظر گرفته شد.

هر یک از گره‌های واقع در لایه پنهان با یک تابع انتقال (f) مشخص می‌شوند که سیگنال ورودی را انتقال می‌دهند. برای p امین الگوی ورودی (X_p) پاسخ z امین گره پنهان (y_j) برابر است با (Kalra et al., 2005):

$$y_j = f\left(\frac{\|X^p - U_j\|}{2\sigma_j^2}\right) \quad (6)$$

که در آن $\|X^p - U_j\|$ فاصله هندسی، U_j مرکز z امین تابع با پایه شعاعی و σ_j واریانس توابع با پایه شعاعی هست که توسط کاربر تعریف می‌گردد. خروجی شبکه با استفاده از مجموع وزن دار خطی پاسخ‌های لایه‌ی پنهان در هر یک از گره‌های خروجی به دست می‌آید. خروجی k امین گره در لایه خروجی (Z_{kj}) از رابطه زیر محاسبه می‌شود:

$$Z_k = \sum_{j=1}^{N_H} y_j w_{kj} \quad (7)$$

که در آن w_{kj} وزن پیوند بین گره‌های پنهان و خروجی و N_H تعداد گره لایه پنهان هست. از متداول‌ترین توابع انتقال RBF، گاوسی و سیگموئیدی می‌باشند.

۲-۴- شاخص‌های ارزیابی شبکه‌ها

برای مقایسه هیدروگراف مشاهداتی با هیدروگراف شبیه‌سازی شده در مراحل واسنجی و صحت‌سنجی مدل، شاخص‌های نکویی برازش مختلفی را می‌توان استفاده نمود. این شاخص‌ها به دو گروه معیارهای گرافیکی و پارامترهای آماری سنجش خطا قابل تقسیم هستند. از دسته معیارهای گرافیکی می‌توان به ترسیم هیدروگراف جریان مشاهداتی و شبیه‌سازی شده در کنار هم اشاره نمود. از شاخص‌های آماری سنجش خطا می‌توان به ضریب ناش- ساتکلایف^{۲۷}، ریشه میانگین مربعات خطا^{۲۸}، میانگین قدمطلق درصد خطا^{۲۹}، درصد خطای حجمی کل^{۳۰} و اشاره کرد که به ترتیب در روابط (۸) تا (۱۱) آمده است. ضریب ناش- ساتکلایف بیانگر راندمان مدل بوده که اخیراً در مسائل هیدرولوژی به‌وفور مورد استفاده قرار گرفته است. ضریب ناش- ساتکلایف می‌تواند مقداری از منفی بی نهایت تا یک را به خود اختصاص دهند که عدد یک نشان‌دهنده برازش کامل و انطباق ۱۰۰٪ بین مقادیر مشاهداتی و شبیه‌سازی شده می‌باشد. در روابط (۸) تا (۱۱)، n برابر با تعداد داده‌های جریان، O_i و S_i داده‌های جریان مشاهداتی و شبیه‌سازی شده در گام زمانی i ام، \bar{O} دبی میانگین مشاهده‌ای و Cov کوواریانس داده‌ها می‌باشد (Nash and Sutcliffe, 1970; Abrahart et al., 2004).

$$NS = 1 - \left[\frac{\sum_{i=1}^n (S_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \right] \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_i - O_i)^2} \quad (9)$$

Table 6- PMI results for single criterion rainfall-runoff model

جدول ۶- نتایج الگوریتم PMI برای مدل تک ضابطه‌ای بارش- رواناب

Iteration	Variable	I(x;y)	MC-I*(95)	MC-I*(99)	Hampel
0	LOGQIdanak(t-1)	3.030	0.038	0.041	3.491
1	LOGQIdanak(t-2)	0.324	0.038	0.041	3.649
2	LOGQIdanak(t-3)	0.219	0.038	0.041	1.672
3	LOGQIdanak(t-7)	0.176	0.038	0.041	0.075
4	LOGQIdanak(t-4)	0.128	0.038	0.041	1.854
5	LOGQIdanak(t-6)	0.128	0.038	0.041	1.349

Table 7- PMI results for dual criteria rainfall-runoff model for rainy days

جدول ۷- نتایج الگوریتم PMI برای مدل دوضابطه‌ای بارش- رواناب، بخش مربوط به روزهای بارانی

Iteration	Variable	I(x;y)	MC-I*(95)	MC-I*(99)	Hampel
0	powRidanak(t-1)	-0.145	0.041	0.045	2.812
1	powRAlgan(t-1)	-0.063	0.041	0.045	7.046
2	powRidanak(t-2)	-0.056	0.041	0.045	2.562
3	powRAlgan(t)	-0.038	0.041	0.045	5.435
4	powRidanak(t)	-0.035	0.041	0.045	1.872
5	powRAlgan(t-2)	-0.053	0.041	0.045	1.795
6	powRidanak(t-3)	-0.008	0.041	0.045	1.647
7	powRidanak(t-4)	-0.027	0.041	0.045	0.894
8	powRidanak(t-6)	-0.012	0.041	0.045	0.393
9	powRidanak(t-7)	-0.014	0.041	0.045	2.266
10	powRAlgan(t-7)	-0.008	0.041	0.045	1.456
11	powRAlgan(t-4)	-0.032	0.041	0.045	0.674
12	powRAlgan(t-3)	-0.050	0.041	0.045	0.319
13	powRidanak(t-5)	-0.067	0.041	0.045	3.585
14	powRAlgan(t-5)	-0.074	0.041	0.045	1.151

Table 8- PMI results for dual criteria rainfall-runoff model for non-rainy days

جدول ۸- نتایج الگوریتم PMI برای مدل دوضابطه‌ای بارش- رواناب، بخش مربوط به روزهای غیربارانی

Iteration	Variable	I(x;y)	MC-I*(95)	MC-I*(99)	Hampel
0	LOGQIdanak(t-1)	3.030	0.038	0.042	3.491
1	LOGQIdanak(t-2)	0.325	0.038	0.042	3.649
2	LOGQIdanak(t-3)	0.219	0.038	0.042	1.672
3	LOGQIdanak(t-7)	0.177	0.038	0.042	0.075
4	LOGQIdanak(t-4)	0.128	0.038	0.042	1.855
5	LOGQIdanak(t-6)	0.128	0.038	0.042	1.349

مدل های شبکه MLP در شبیه‌سازی پیوسته بارش- رواناب مربوط به مدل تک‌ضابطه‌ای و دوضابطه‌ای در حوضه مارون را نشان می‌دهد. همچنین مشخصات بهترین ساختار آموزش مدل‌های شبکه RBF در شبیه‌سازی پیوسته بارش- رواناب مربوط به مدل تک‌ضابطه‌ای و دوضابطه‌ای در جدول ۱۰ نشان داده شده است.

سپس اقدام به آموزش و آزمون هر یک از شبکه‌ها گردید و به ازای هر شبکه ضریب ناش- ساتکلایف و ریشه میانگین مربعات خطا بین دبی جریان مشاهداتی و محاسباتی با شبکه عصبی مصنوعی محاسبه گردید. برای اجرای مدل شبکه عصبی مصنوعی از نرم‌افزار MATLAB استفاده شد. جدول ۹ مشخصات بهترین ساختار آموزش

به ازای دو مرحله آموزش و آزمون شبکه را نشان می‌دهد. در جدول ۱۱ NS، RMSE، MAPE و PTVE به ترتیب ضریب ناش-ساتکلایف، ریشه میانگین مربعات خطا بر حسب مترمکعب در ثانیه، میانگین قدرمطلق درصد خطا و درصد خطای حجم کل بین هیدروگراف جریان مشاهداتی و شبیه‌سازی شده می‌باشد.

با توجه به شاخص‌های آماری برای مدل تک‌ضابطه‌ای در جدول ۱۱ می‌توان دریافت که شبکه RBF از دقت بیشتری نسبت به شبکه MLP برخوردار می‌باشد. همچنین با توجه به شاخص‌های آماری برای بخش روزهای بارانی و روزهای غیربارانی مدل دوضابطه‌ای در جدول ۱۱ می‌توان دریافت که شبکه MLP از دقت و توانایی بیشتری نسبت به شبکه RBF در برآورد جریان در روزهای بارانی در حوضه مارون برخوردار می‌باشد. البته دقت شبکه MLP مربوط به روزهای غیربارانی بیشتر از روزهای بارانی می‌باشد، به طوری که ضریب ناش-ساتکلایف برای مرحله آزمون شبکه MLP در بخش روزهای غیربارانی مدل دوضابطه‌ای برابر با ۰/۹۵ و بخش روزهای بارانی مدل دوضابطه‌ای برابر با ۰/۹۳ می‌باشد.

همچنین با بررسی و مقایسه مقادیر شاخص‌های آماری بین مدل تک ضابطه‌ای و مدل دوضابطه‌ای کلی (شامل روزهای بارانی و غیربارانی) در جدول ۱۱ می‌توان دریافت که دقت مدل دوضابطه‌ای در برآورد دبی جریان در ایستگاه هیدرومتری ایدنک بیشتر از دقت مدل تک‌ضابطه‌ای می‌باشد.

با توجه به جدول ۹ می‌توان دریافت که شبکه MLP با ساختار ۱-۵-۲ (یعنی ۲ نرون ورودی، ۵ نرون در لایه میانی و یک نرون برای لایه خروجی) با ۱۰۰۰ تکرار آموزش به ازای تابع انتقال Tansig (تانزانت سیگموئید) و الگوریتم آموزش Traingdm (کاهش گرادیان همراه با مومنتم)، بهترین شبکه MLP مربوط به مدل تک‌ضابطه‌ای بارش-رواناب می‌باشد؛ بطوری که ضریب ناش-ساتکلایف بین دبی جریان مشاهداتی و محاسباتی با شبکه MLP مربوط به مدل تک‌ضابطه‌ای به ازای مرحله آموزش و آزمون به ترتیب برابر با ۰/۸۸ و ۰/۸۴ است. علاوه بر این، با توجه به جدول ۱۰ می‌توان دریافت که شبکه RBF با ساختار ۱-۹-۴ (یعنی ۴ گره ورودی، ۹ گره در لایه پنهان و یک نرون برای لایه خروجی) با ۲۲۵۰ تکرار آموزش به ازای مقدار ضریب پراکنش برابر با ۰/۶، بهترین شبکه RBF مربوط به بخش روزهای بارانی مدل دوضابطه‌ای بارش-رواناب می‌باشد.

۲-۳- مقایسه مدل‌های تک‌ضابطه‌ای و دوضابطه‌ای بارش-رواناب شبکه عصبی مصنوعی

به منظور مقایسه مدل‌های تک‌ضابطه‌ای و دوضابطه‌ای شبکه عصبی مصنوعی MLP و RBF در شبیه‌سازی پیوسته فرآیند بارش-رواناب در حوضه مارون، هیدروگراف جریان مشاهداتی و شبیه‌سازی شده در مرحله آزمون شبکه هم از لحاظ شکل تغییرات و هم از نظر شاخص‌های آماری با یکدیگر مقایسه شدند. جدول ۱۱ شاخص‌های آماری بین هیدروگراف جریان مشاهداتی و شبیه‌سازی شده با مدل‌های تک‌ضابطه‌ای و دوضابطه‌ای شبکه عصبی مصنوعی MLP و RBF

Table 9- Characteristics of the best structure of MLP network in continuous rainfall-runoff simulation
جدول ۹- مشخصات بهترین ساختار آموزش مدل‌های شبکه MLP در شبیه‌سازی پیوسته بارش-رواناب

Model	Structure	Training Algorithm	Transformation function	Epoch	Train		Test	
					NS	RMSE (cms)	NS	RMSE (cms)
Single criterion	2-5-1	Traingdm	Tansig	1000	0.88	39.42	0.84	22.48
Dual criteria (rainy days)	4-6-1	Trainlm	Tansig	1000	0.95	49.87	0.93	30.14
Dual criteria (non- rainy days)	2-3-1	Trainlm	Logsig	1500	0.94	11.59	0.95	7.04

Table 10- Characteristics of the best structure of RBF network in continuous rainfall-runoff simulation
جدول ۱۰- مشخصات بهترین ساختار آموزش مدل‌های شبکه RBF در شبیه‌سازی پیوسته بارش-رواناب

Model	Structure	Spread	Epoch	Train		Test	
				NS	RMSE (cms)	NS	RMSE (cms)
Single criterion	2-3-1	0.3	2000	0.92	34.95	0.86	21.19
Dual criteria (rainy days)	4-9-1	0.6	2250	0.91	64.41	0.87	39.36
Dual criteria (non-rainy days)	2-4-1	0.8	3000	0.93	13.59	0.95	7.15

Table 11- Statistical indicators for observed and simulated hydrographs with artificial neural network by single criterion and dual criteria models

جدول ۱۱- شاخص‌های آماری بین هیدروگراف جریان مشاهداتی و شبیه‌سازی شده با مدل‌های تک‌ضابطه‌ای و دوضابطه‌ای شبکه عصبی مصنوعی MLP و RBF

Model	Network	State	Criteria			
			NS	RMSE (cms)	MAPE (%)	PTVE (%)
Single criterion	MLP	train	0.88	39.42	29.84	-0.27
		test	0.84	22.48	32.34	-0.19
	RBF	train	0.92	34.95	26.33	-0.88
		test	0.86	21.19	29.66	-0.53
Dual criteria	MLP	train	0.95	49.87	17.42	1.09
		test	0.93	30.14	18.95	2.49
	RBF	train	0.91	64.41	28.60	1.10
		test	0.87	39.36	24.76	-0.50
Dual criteria	MLP	train	0.94	11.59	17.46	1.22
		test	0.95	7.04	15.28	-0.31
	RBF	train	0.93	13.59	17.75	1.63
		test	0.95	7.15	15.39	0.13
Dual criteria	MLP	train	0.95	24.09	17.45	1.16
		test	0.94	13.60	15.86	0.66

شکل‌های ۴ و ۵ می‌توان دریافت که شکل تغییرات هیدروگراف جریان شبیه‌سازی شده با مدل دوضابطه‌ای نزدیکتر به هیدروگراف جریان مشاهداتی نسبت به هیدروگراف شبیه‌سازی شده با مدل تک‌ضابطه‌ای می‌باشد.

۴- نتیجه‌گیری

نتایج این تحقیق نشان می‌دهد که بکارگیری الگوریتم PMI جهت تعیین متغیرهای ورودی مؤثر در شبکه‌های عصبی مصنوعی موجب افزایش دقت شبکه‌ها در شبیه‌سازی پیوسته بارش- رواناب می‌گردد. علاوه بر این استفاده از الگوریتم PMI موجب کاهش قابل توجه در زمان موردنیاز برای تعیین متغیرهای ورودی مؤثر و در نتیجه توسعه مدل می‌گردد. (May et al. (2008) با مقایسه نتایج مدل ANN توسعه‌یافته با الگوریتم PMI با نتایج مدل ANN بدون بکارگیری الگوریتم PMI، دریافتند که مدل توسعه یافته با الگوریتم PMI از دقت پیش‌بینی بیشتری همراه با صرفه‌جویی قابل توجه در توسعه مدل برخوردار است. (Chang et al. (2017) دریافتند که دقت مدل ANFIS که متغیرهای ورودی آن با مدل ترکیبی اطلاعات متقابل و تحلیل همبستگی انتخاب شده، در برآورد دبی پیک بیشتر از مدل ANFIS که متغیرهای ورودی آن با تحلیل همبستگی تعیین شده می‌باشد.

به‌طوری که ضریب ناش- ساتکالیف برای مدل تک‌ضابطه‌ای و دوضابطه‌ای به ازای مرحله آموزش شبکه به ترتیب برابر با ۰/۹۲ و ۰/۹۵ می‌باشد. همچنین ضریب ناش- ساتکالیف برای مدل تک‌ضابطه‌ای و دوضابطه‌ای به ازای مرحله آزمون شبکه به ترتیب برابر با ۰/۸۶ و ۰/۹۴ می‌باشد. علاوه بر این ریشه میانگین مربعات خطا بین هیدروگراف مشاهداتی و محاسباتی با مدل تک‌ضابطه‌ای و دوضابطه‌ای به ازای مرحله آموزش شبکه به ترتیب برابر با ۳۴/۹۵ و ۲۴/۰۹ مترمکعب در ثانیه می‌باشد. همچنین ریشه میانگین مربعات خطا بین هیدروگراف مشاهداتی و محاسباتی با مدل تک‌ضابطه‌ای و دوضابطه‌ای به ازای مرحله آزمون شبکه به ترتیب برابر با ۲۱/۱۹ و ۱۳/۶ مترمکعب در ثانیه می‌باشد. علاوه بر این میانگین قدرمطلق درصد خطا بین هیدروگراف مشاهداتی و شبیه‌سازی شده با مدل تک‌ضابطه‌ای و دوضابطه‌ای به ازای مرحله آموزش شبکه به ترتیب برابر با ۲۶/۳۳ و ۱۷/۴۵ درصد می‌باشد. همچنین میانگین قدرمطلق درصد خطا بین هیدروگراف مشاهداتی و محاسباتی با مدل تک‌ضابطه‌ای و دوضابطه‌ای به ازای مرحله آزمون شبکه به ترتیب برابر با ۲۹/۶۶ و ۱۵/۸۶ درصد می‌باشد. شکل ۴ مقایسه هیدروگراف جریان مشاهداتی و شبیه‌سازی شده با مدل تک‌ضابطه‌ای و دوضابطه‌ای به ازای مرحله آموزش شبکه را نشان می‌دهد. همچنین مقایسه هیدروگراف جریان مشاهداتی و شبیه‌سازی شده با مدل تک‌ضابطه‌ای و دوضابطه‌ای به ازای مرحله آزمون شبکه در شکل ۵ نشان داده شده است. با توجه به

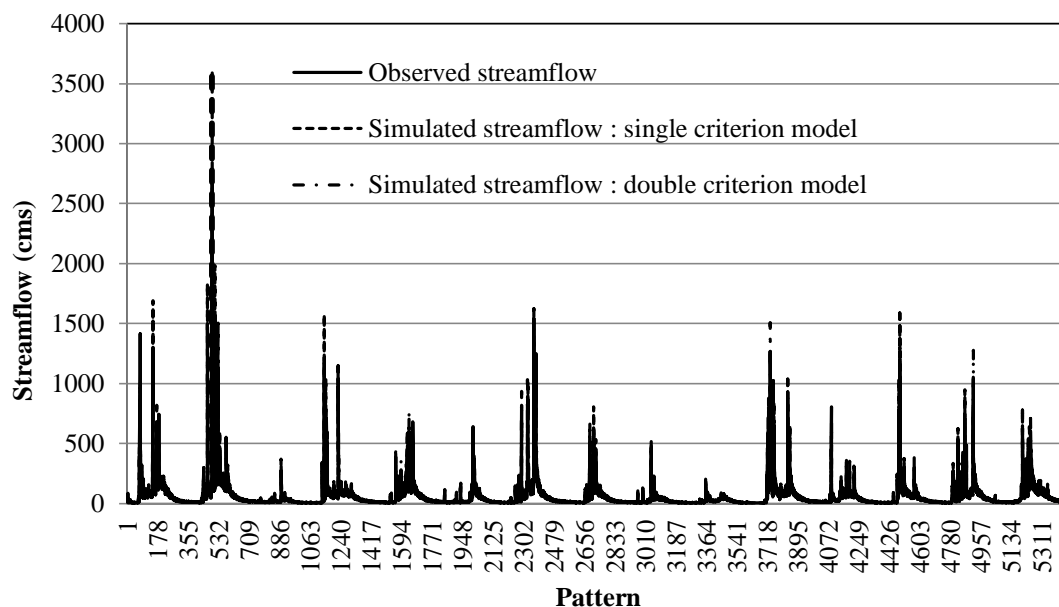


Fig. 4- Comparison of observed and simulated hydrographs with the single criterion and dual criteria rainfall-runoff model in network training stage

شکل ۴- مقایسه هیدروگراف جریان مشاهداتی و شبیه‌سازی شده با مدل تک ضابطه‌ای و دوضابطه‌ای بارش- رواناب به ازای مرحله آموزش شبکه

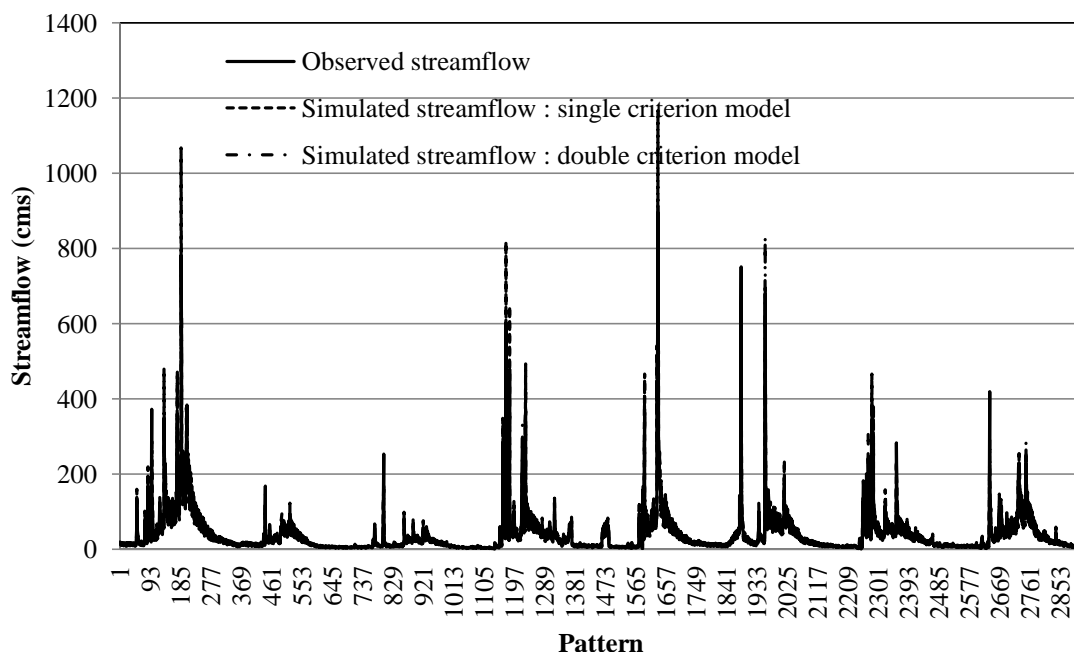


Fig. 5- Comparison of observed and simulated hydrographs with the single criterion and dual criteria rainfall-runoff model in network testing stage

شکل ۵- مقایسه هیدروگراف جریان مشاهداتی و شبیه‌سازی شده با مدل تک ضابطه‌ای و دوضابطه‌ای به ازای مرحله آزمون شبکه

نتایج حاصل از بکارگیری الگوریتم PMI جهت تعیین متغیرهای ورودی مؤثر بر دبی جریان در مدل تک ضابطه‌ای بارش- رواناب با استفاده از مدل‌های بر مبنای پردازش داده‌ها نشان می‌دهد که مقادیر دبی جریان یک روز قبل و دو روز قبل در ایستگاه هیدرومتری،

- 11- Radial Based Function Neural Network (RBFNN)
- 12- Back Propagation Neural Network (BPNN)
- 13- Ensemble Empirical Mode Decomposition (EEMD)
- 14- Confidence Bounds
- 15- Bootstrap Loop
- 16- Shannon Entropy
- 17- Marginal Probability Density Functions
- 18- Joint Probability Density Function
- 19- Venn Diagram
- 20- Tabulated Critical Values
- 21- Akaike Information Criterion
- 22- Hampel Test Criterion
- 23- White-Noise
- 24- Kernel Density Estimation
- 25- Median Absolute Deviation
- 26- PlugIn
- 27- Nash-Sutcliffe (NS)
- 28- Root Mean Square Error (RMSE)
- 29- Mean Absolute of Percent Error (MAPE)
- 30- Percent of Total Volume Error (PTVE)

۵- مراجع

- Abrahart R, Kneale PE, and See LM (2004) Neural networks for hydrological modeling. CRC Press, 316p
- Akaike H (1974) A new look at the statistical model identification. IEEE Transactions on Automatic Control 19:716-723
- Anusree K and Varghese KO (2016) Streamflow prediction of Karuvannur river basin using ANFIS, ANN and MNLN models. Procedia Technology 24:101-108
- Araghinejad S and Karamouz M (2005) Long-lead streamflow forecasting using artificial neural networks and fuzzy inference system. Iran Water Resources Research 1(2):29-41 (In Persian)
- Bowden GJ, Maier HR, and Dandy GC (2005) Input determination for neural network models in water resources applications. Part 2. Case study: Forecasting salinity in a river. Journal of Hydrology 301(1-4):93-107
- Chang TK, Talei A, Alaghmand S and Ooi MPL (2017) Choice of rainfall inputs for event-based rainfall-runoff modeling in a catchment with multiple rainfall stations using data-driven techniques. Journal of Hydrology 545:100-108
- Cover TM and Thomas JA (1991) Elements of information theory. John Wiley & Sons, Inc., New York, 776p
- Dastorani MT, Sharifi Darani H, Talebi A, Moghadam Nia A (2011) Evaluation of the application of

متغیرهای ورودی مؤثر می‌باشند. در روزهای بارانی مربوط به مدل دوضابطه‌ای بارش- رواناب به علت آنکه جریان ناشی از وقوع بارش و عمدتاً بصورت سیلابی بوده، بنابراین متغیرهای مؤثر بر دبی جریان در ایستگاه هیدرومتری شامل مقادیر بارش زمان حال، بارش یک روز قبل و بارش دو روز قبل در ایستگاه‌های بارانسنجی هستند. همچنین با توجه به مقدار PMI و فاصله همپل حاصل از بکارگیری الگوریتم PMI، تأثیر بارش یک روز قبل در ایستگاه‌های بارانسنجی بیشتر از بارش دو روز قبل می‌باشد که به علت زمان تمرکز نسبتاً کم و واکنش سریع حوضه مارون نسبت به وقوع بارش می‌باشد. علاوه بر این در روزهای غیربارانی مربوط به مدل دوضابطه‌ای بارش- رواناب، به علت آنکه جریان عبوری در ایستگاه هیدرومتری بصورت جریان پایه بوده بنابراین متغیرهای مؤثر بر دبی جریان شامل مقادیر دبی جریان یک روز قبل و دو روز قبل در ایستگاه هیدرومتری هستند. به عبارتی هنگامی که کل داده‌ها شامل روزهای بارانی و غیربارانی جهت مدل تک‌ضابطه‌ای بارش- رواناب در نظر گرفته شود، به علت اینکه تعداد روزهای بارانی در هر سال خیلی کمتر از تعداد روزهای غیربارانی است، متغیرهای مؤثر بر دبی جریان در ایستگاه هیدرومتری مشابه بخش مربوط به روزهای غیربارانی مدل دوضابطه‌ای بارش- رواناب فقط شامل دبی جریان یک روز قبل و دو روز قبل خواهد بود. از دیگر نتایج این تحقیق آن است که تفکیک داده‌ها به دو دسته روزهای بارانی و غیربارانی و تهیه مدل دوضابطه‌ای بارش- رواناب موجب افزایش دقت شبکه عصبی مصنوعی در شبیه‌سازی پیوسته بارش- رواناب می‌گردد. به عبارتی دقت مدل دوضابطه‌ای بارش- رواناب در برآورد دبی جریان در ایستگاه هیدرومتری بیشتر از دقت مدل تک‌ضابطه‌ای بارش- رواناب می‌باشد. بنابراین پیشنهاد می‌گردد که برای مدل‌سازی پیوسته بارش- رواناب در حوضه‌های آبریز با استفاده از مدل‌های بر مبنای پردازش داده‌ها، مدل دوضابطه‌ای بارش- رواناب شامل روزهای بارانی و غیربارانی تهیه شود.

پی‌نوشت‌ها

- 1- Partial Mutual Information
- 2- Self Organizing Map-Genetic Algorithm and General Regression Neural Network (SOM-GAGRNN)
- 3- Input Variable Selection
- 4- Reference Evapotranspiration
- 5- Partial Linear Correlation
- 6- Extreme Eastern Tropical Pacific SST (0-10S, 90 W-80 W)
- 7- El Niño-Southern Oscillation
- 8- Support Vector Regression
- 9- Random Forest
- 10- Multiple Linear Regression

- Khaleghi M, Ghodosi J, Ahmadi H, and Kamyar M (2010) Hydrograph methods for performance evaluation Geomorphological instantaneous unit estimate peak flood discharge. *Journal of Science and Technology of Agriculture and Natural Resources, Water and Soil Sciences* 5:89-100 (In Persian)
- Kisi O (2007) Streamflow forecasting using different artificial neural network algorithms. *Journal of Hydrologic Engineering* 12(5):532-539
- Kisi O (2010) Wavelet regression model for short-term streamflow forecasting. *Journal of Hydrology* 389(3-4):344-353
- Kurtulus B and Razack M (2010) Modeling daily discharge responses of a large karstic aquifer using soft computing methods: Artificial neural network and neuro-fuzzy. *Journal of Hydrology* 381(1-2):101-111
- Lee SC, Lin HT, and Yang TY (2010) Artificial neural network analysis for reliability prediction of regional runoff utilization. *Environmental Monitoring and Assessment* 161(1-4):3150-326
- May RJ, Dandy GC, Maier HR, and Fernando TMKG (2006) Critical values of a kernel-density based mutual information estimator. In: *Proc. of the IEEE International Joint Conference on Neural Networks, Vancouver*, 4898-4903
- May RJ, Maier HR, Dandy GC, and Fernando TMKG (2008) Non-linear variable selection for artificial neural networks using partial mutual information. *Environmental Modelling & Software* 23(10):1312-1326
- May RJ, Dandy GC, Maier HR, and Nixon JB (2008) Application of partial mutual information variable selection to ANN forecasting of water quality in water distribution systems. *Environmental Modelling and Software* 23(10-11):1289-1299
- Miguélez M, Puertas J, and Rabuñal JR (2009) Artificial neural networks in urban runoff forecast. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 5517 LNCS(PART 1):1192-1199
- Nabizadeh M, Mosaedi A, Dehghani AA (2012) Intelligent estimation of streamflow by adaptive neuro-fuzzy inference system. *Journal of Water and Irrigation Management* 2:69-80 (In Persian)
- Nash JE and Sutcliffe JV (1970) River flow forecasting through conceptual models; part I: A discussion of principles. *Journal of Hydrology* 10:282-290
- Nourani V, Keynezhad M, and Makani L (2009) Using adaptive neuro-fuzzy inference system rainfall-artificial neural networks and adaptive neuro-fuzzy inference systems for rainfall-runoff modelling in Zayandehrood dam basin. *Iranian Journal of Water and Wastewater* 22:114-125 (In Persian)
- David FN (1966) Tables of the correlation coefficient. In: *Pearson ES, Hartley HO (Eds.) Biometrika tables for statisticians*, 3rd ed., vol. 1. Cambridge University Press, Cambridge
- Davies L and Gather U (1993) The identification of multiple outliers. *Journal of the American Statistical Association* 88(423):782-792
- Dehghani M, Morid S, and Norouzi A (2010) Runoff simulation in snowbound catchments using SRM and ANN models to estimate hydropower potentials in data scarcity situations. *Iran-Water Resources Research* 6(3):12-24 (In Persian)
- El-Shafie A, Mukhlisin M, Najah AA and Taha MR (2011) Performance of artificial neural network and regression techniques for rainfall runoff prediction. *International Journal of Physical Sciences* 6(8):1997-2003
- Fang W, Huang S, Huang Q, Huang G, Meng E, and Luan J (2018) Reference evapotranspiration forecasting based on local meteorological and global climate information screened by partial mutual information. *Journal of Hydrology* 561:764-779
- Ghafari GA and Vafakhah M (2013) Simulation of rainfall-runoff process using artificial neural network and adaptive neuro-fuzzy inference system (Case study: Hajighoshan watershed). *Journal of Watershed Management Research* 4(8):120-136
- Ghorbani, MA, Azani A, and Mahmoudi Vanolya S (2015) Rainfall-runoff modeling using hybrid intelligent models. *Iran-Water Resources Research* 11(2):146-150 (In Persian)
- Goebel B, Dawy Z, Hagenauer J, and Mueller JC (2005) An approximation to the distribution of finite sample size mutual information estimates. In: *IEEE International Conference on Communications (ICC-05)*, Seoul, South Korea
- Granger CW, Maasoumi E, and Racine J (2004) A dependence metric for possibly nonlinear processes. *Journal of Time Series Analysis* 25(5):649-669
- Haghizadeh A, Mohammadlou M, and Noori F (2015) Rainfall-runoff simulation using ANN and ANFIS and MLR (Case study: Khorramabad watershed). *Iranian Journal of Ecohydrology* 2(2):233-243 (In Persian)
- Kalra R, Deo MC, Kumar R, and Agarwal VK (2005) RBF network for spatial mapping of wave heights. *Marine Structures* 18(3):289-300

- Sharma A (2000) Seasonal to interannual rainfall probabilistic forecasts for improved water supply management: part 1: A strategy for system predictor identification. *Journal of Hydrology* 239:232-239
- Tan Q-f, Lei X-h, Wang X, Wang H, Wen X, Ji Y, and Kang A-q (2018) An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach. *Journal of Hydrology* 567:767-780
- Toker AS and Markus M (2000) Precipitation-runoff modeling using artificial neural network and conceptual models. *Journal of Hydrologic Engineering* 5:156-161
- Zareazadeh-Mehrizi M and Bozorg Hadad O (2010) Inflow simulation and forecasting optimization using hybrid ANN-GA algorithm. *Journal of Water and Soil* 24(5):942-954 (In Persian)
- runoff modeling. *Journal of Civil and Environmental Engineering* 39:75-81 (In Persian)
- Pearson RK (2002) Outliers in process modeling and identification. *IEEE Transactions on Control Systems Technology* 10(1):55-63
- Salajegheh A, Fathabadi A, and Mahdavi M (2009) Investigation on the efficiency of neuro-fuzzy method and statistical models in simulation of rainfall-runoff process. *Journal of Range and Watershed Management. Iranian Journal of Natural Resources* 62:65-79 (In Persian)
- Shahverdi K and Samani JMV (2010) Automated simulation of basin characteristics using HEC-HMS, genetic algorithm, and AutoIt on observed hydrograph properties. *Iran-Water Resources Research* 6(3):96-99 (In Persian)
- Shannon CE (1948) A mathematical theory of communication. *Bell System Technical Journal* 27:379-423